

# Modelos de Vectores Autoregresivos (VAR)

## Macroeconometría Aplicada

Juan Guerra-Salas

Pontificia Universidad Católica de Chile

Segundo Semestre 2020

- ▶ Sacaré contenido de **Cochrane, cáp. 5**.
- ▶ Aprendieron sobre modelos ARMA univariados; modelos que analizan la evolución de una serie de tiempo.
- ▶ Los modelos multivariados son útiles para describir la evolución conjunta de múltiples series de tiempo.
- ▶ Los modelos multivariados permiten capturar interdependencias entre variables.
- ▶ Por ejemplo, es probable que el PIB, la inflación y la tasa de política monetaria estén relacionadas (la teoría soporta esta idea).
- ▶ Hablamos de “vectores autoregresivos” (VARs), porque es poco común estimar términos de media móvil. Los procesos autoregresivos son más fáciles de estimar (supuestos de MCO aplican).

- 1 Notación
- 2 El proceso VAR(1)
- 3 Expresión de un VAR(p) como un VAR(1)
- 4 Pronósticos con VARs
- 5 Aplicación: Pronósticos de la inflación

- ▶ Los símbolos con negrita indican vectores y matrices.
- ▶ Consideren la siguiente serie multivariada (bivariada):

$$\mathbf{x}_t = \begin{bmatrix} y_t \\ z_t \end{bmatrix}.$$

- ▶ El ingrediente principal de nuestros modelos será el proceso ruido blanco multivariado  $\epsilon_t \sim \text{iid } N(\mathbf{0}, \mathbf{\Sigma})$ :

$$\epsilon_t = \begin{bmatrix} \delta_t \\ \nu_t \end{bmatrix}; \quad E(\epsilon_t) = \mathbf{0}; \quad E(\epsilon_t \epsilon_t') = \mathbf{\Sigma} = \begin{bmatrix} \sigma_\delta^2 & \sigma_{\delta,\nu} \\ \sigma_{\delta,\nu} & \sigma_\nu^2 \end{bmatrix}; \quad E(\epsilon_t \epsilon_{t-j}') = \mathbf{0}.$$

# El proceso VAR(1)

- ▶ Conocemos el proceso univariado AR(1):  $x_t = \phi x_{t-1} + \epsilon_t$ .
- ▶ Ahora estudiamos su versión multivariada, el VAR(1). Consideren el siguiente proceso VAR(1) bivariado:

$$\mathbf{x}_t = \mathbf{\Phi} \mathbf{x}_{t-1} + \epsilon_t,$$

$$\begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} \phi_{yy} & \phi_{yz} \\ \phi_{zy} & \phi_{zz} \end{bmatrix} \begin{bmatrix} y_{t-1} \\ z_{t-1} \end{bmatrix} + \begin{bmatrix} \delta_t \\ \nu_t \end{bmatrix},$$

$$y_t = \phi_{yy} y_{t-1} + \phi_{yz} z_{t-1} + \delta_t$$

$$z_t = \phi_{zy} y_{t-1} + \phi_{zz} z_{t-1} + \nu_t$$

- ▶ Valores rezagados de ambas variables aparecen en ambas ecuaciones.
- ▶ Ejemplo: VAR con PIB y tasa de política monetaria (TPM). Podría capturar: si la TPM es baja este periodo, el PIB sería más alto el próximo periodo; y/o si el PIB es alto este periodo, va a tender a ser algo el siguiente periodo.

## Expresión de un VAR(p) como un VAR(1) (1/3)

- ▶ La especificación VAR(1) facilita el cálculo de pronósticos, varianzas del error de pronóstico (y otras cosas), porque se pueden obtener de manera recursiva.
- ▶ Cualquier proceso ARMA or VAR se puede expresar como un VAR(1).
- ▶ Por ejemplo, consideren el siguiente proceso ARMA(2,1):

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \epsilon_t + \theta_1 \epsilon_{t-1}.$$

- ▶ Es equivalente a:

$$\begin{bmatrix} y_t \\ y_{t-1} \\ \epsilon_t \end{bmatrix} = \begin{bmatrix} \phi_1 & \phi_2 & \theta_1 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} y_{t-1} \\ y_{t-2} \\ \epsilon_{t-1} \end{bmatrix} + \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix} \epsilon_t,$$

$$\mathbf{x}_t = \mathbf{A}\mathbf{x}_{t-1} + \mathbf{C}\mathbf{w}_t$$

# Expresión de un VAR(p) como un VAR(1) (2/3)

- ▶ Consideren un VAR bivariado de orden arbitrario  $p$ :

$$y_t = \phi_{yy1}y_{t-1} + \phi_{yy2}y_{t-2} + \dots + \phi_{yz1}z_{t-1} + \phi_{yz2}y_{t-2} + \dots + \epsilon_{yt}$$

$$z_t = \phi_{zy1}y_{t-1} + \phi_{zy2}y_{t-2} + \dots + \phi_{zz1}z_{t-1} + \phi_{zz2}y_{t-2} + \dots + \epsilon_{zt}$$

- ▶ Puede expresarse como un VAR(1) en el vector

$$\mathbf{x}_t = [y_t \ z_t \ y_{t-1} \ z_{t-1} \ \dots]'$$

$$\underbrace{\begin{bmatrix} y_t \\ z_t \\ y_{t-1} \\ z_{t-1} \\ \vdots \end{bmatrix}}_{(2p \times 1)} = \underbrace{\begin{bmatrix} \phi_{yy1} & \phi_{yz1} & \phi_{yy2} & \phi_{yz2} & \cdots \\ \phi_{zy1} & \phi_{zz1} & \phi_{zy2} & \phi_{zz2} & \cdots \\ 1 & 0 & 0 & 0 & \cdots \\ 0 & 1 & 0 & 0 & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{bmatrix}}_{(2p \times 2p)} \underbrace{\begin{bmatrix} y_{t-1} \\ z_{t-1} \\ y_{t-2} \\ z_{t-2} \\ \vdots \end{bmatrix}}_{(2p \times 1)} + \underbrace{\begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \\ 0 & 0 \\ \vdots & \vdots \end{bmatrix}}_{(2p \times 2)} \underbrace{\begin{bmatrix} \epsilon_{yt} \\ \epsilon_{zt} \end{bmatrix}}_{(2p \times 1)}, \text{ or}$$

$$\mathbf{x}_t = \mathbf{A}\mathbf{x}_{t-1} + \mathbf{C}\epsilon_t, \quad E(\epsilon_t\epsilon_t') = \Sigma$$

## Expresión de un VAR( $p$ ) como un VAR(1) (3/3)

- ▶ Expresamos un VAR bivariado de orden arbitrario  $p$  como un VAR(1). Los elementos de vectores y matrices en esta representación son escalares.
- ▶ Se puede obtener un VAR(1) equivalente, en el que los elementos de vectores y matrices de la representación también son vectores y matrices:

$$\mathbf{x}_t = \Phi_1 \mathbf{x}_{t-1} + \Phi_2 \mathbf{x}_{t-2} + \dots + \Phi_p \mathbf{x}_{t-p} + \epsilon_t$$

- ▶ We would map this into a VAR(1) as follows:

$$\begin{bmatrix} \mathbf{x}_t \\ \mathbf{x}_{t-1} \\ \mathbf{x}_{t-2} \\ \vdots \\ \mathbf{x}_{t-p+1} \end{bmatrix} = \begin{bmatrix} \Phi_1 & \Phi_2 & \Phi_3 & \cdots & \Phi_p \\ \mathbf{I} & \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{I} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{x}_{t-1} \\ \mathbf{x}_{t-2} \\ \mathbf{x}_{t-3} \\ \vdots \\ \mathbf{x}_{t-p} \end{bmatrix} + \begin{bmatrix} \mathbf{I} \\ \mathbf{0} \\ \mathbf{0} \\ \vdots \\ \mathbf{0} \end{bmatrix} [\epsilon_t]$$



# Pronósticos de un VAR(1) (1/2)

- ▶ Sabemos cómo calcular pronósticos de un proceso escalar AR(1). Para un VAR(1)  $\mathbf{x}_t = \mathbf{A}\mathbf{x}_{t-1} + \mathbf{C}\epsilon_t$ , el proceso es análogo:

$$E_t(\mathbf{x}_{t+k}) = \mathbf{A}^k \mathbf{x}_t.$$

- ▶ La varianza del error de pronóstico:

$$\mathbf{x}_{t+1} - E_t(\mathbf{x}_{t+1}) = \mathbf{A}\mathbf{x}_t + \mathbf{C}\epsilon_{t+1} - \mathbf{A}\mathbf{x}_t = \mathbf{C}\epsilon_{t+1}$$

$$\Rightarrow \text{var}_t[\mathbf{x}_{t+1} - E_t(\mathbf{x}_{t+1})] = \text{var}_t(\mathbf{x}_{t+1}) = \text{var}_t(\mathbf{C}\epsilon_{t+1}) = \mathbf{C}\Sigma\mathbf{C}'$$

$$\mathbf{x}_{t+2} - E_t(\mathbf{x}_{t+2}) = \mathbf{A}\mathbf{x}_{t+1} + \mathbf{C}\epsilon_{t+2} - \mathbf{A}^2\mathbf{x}_t$$

$$= \mathbf{A}(\mathbf{A}\mathbf{x}_t + \mathbf{C}\epsilon_{t+1}) + \mathbf{C}\epsilon_{t+2} - \mathbf{A}^2\mathbf{x}_t = \mathbf{C}\epsilon_{t+2} + \mathbf{A}\mathbf{C}\epsilon_{t+1}$$

$$\Rightarrow \text{var}_t[\mathbf{x}_{t+2} - E_t(\mathbf{x}_{t+2})] = \text{var}_t(\mathbf{x}_{t+2}) = \mathbf{C}\Sigma\mathbf{C}' + \mathbf{A}\mathbf{C}\Sigma\mathbf{C}'\mathbf{A}'$$

$$\text{var}_t(\mathbf{x}_{t+k}) = \sum_{j=0}^{k-1} \mathbf{A}^j \mathbf{C}\Sigma\mathbf{C}' \mathbf{A}^{j'}$$

## Pronósticos de un VAR(1) (2/2)

- Estas fórmulas para pronósticos y errores de varianza de pronósticos pueden expresarse de manera recursiva:

$$E_t(\mathbf{x}_{t+k}) = \mathbf{A}E_t(\mathbf{x}_{t+k-1}), \text{ porque}$$

$$E_t(\mathbf{x}_{t+k}) = \mathbf{A}^k \mathbf{x}_t$$

$$E_t(\mathbf{x}_{t+k-1}) = \mathbf{A}^{k-1} \mathbf{x}_t, \text{ por lo tanto:}$$

$$E_t(\mathbf{x}_{t+k}) = \mathbf{A}\mathbf{A}^{k-1} \mathbf{x}_t = \mathbf{A}E_t(\mathbf{x}_{t+k-1})$$

$$\text{var}_t(\mathbf{x}_{t+k}) = \mathbf{C}\Sigma\mathbf{C}' + \mathbf{A}\text{var}_t(\mathbf{x}_{t+k-1})\mathbf{A}'$$

$$\text{var}_t(\mathbf{x}_{t+2}) = \mathbf{C}\Sigma\mathbf{C}' + \mathbf{A}\mathbf{C}\Sigma\mathbf{C}'\mathbf{A}'$$

$$\text{var}_t(\mathbf{x}_{t+1}) = \mathbf{C}\Sigma\mathbf{C}', \text{ por lo tanto:}$$

$$\text{var}_t(\mathbf{x}_{t+2}) = \mathbf{C}\Sigma\mathbf{C}' + \mathbf{A}\text{var}_t(\mathbf{x}_{t+1})\mathbf{A}'$$

## Aplicación: Pronósticos de la inflación (1/6)

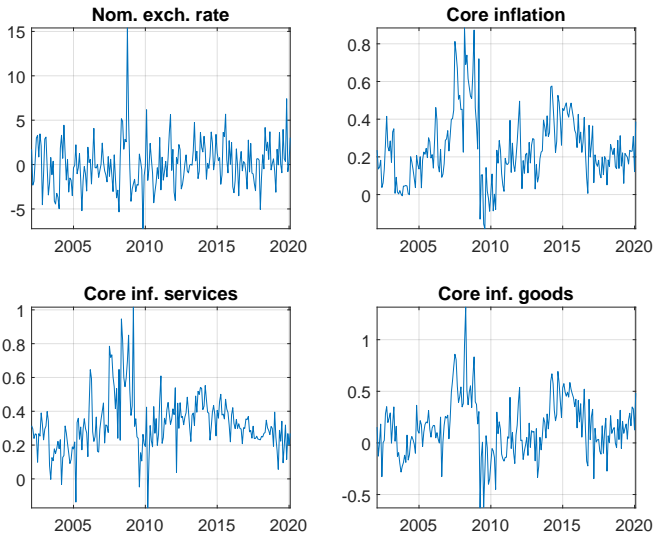
- ▶ Sabemos que la inflación está relacionada con el tipo de cambio nominal.
- ▶ Pronosticamos la inflación con un modelo VAR que incluye ambas variables.
- ▶ Comparamos los pronósticos del modelo VAR con los que provienen de un modelo autoregresivo univariado.
- ▶ Usamos datos mensuales del tipo de cambio nominal (pesos por dólar) y de la inflación sin alimentos y energía (subyacente).
- ▶ Además, la inflación SAE se desagrega en inflación SAE de bienes, e inflación SAE de servicios.
- ▶ La muestra cubre el periodo 2002:M2–2020:M2.
- ▶ Todos los datos se expresan como diferencias logarítmicas multiplicadas por cien, por lo que se aproximan a variaciones porcentuales mensuales.

## Aplicación: Pronósticos de la inflación (2/6)

- ▶ Para cada medida de inflación (SAE, SAE bienes y SAE servicios), usamos un modelo VAR(2) que además incluye al tipo de cambio nominal; y un modelo AR(2).
- ▶ Hacemos un análisis de desempeño predictivo fuera de muestra, que consiste en pronósticos recursivos:
  - Estimamos los modelos para la muestra 2002:M2–2015:M2 y pronosticamos los próximos 6 meses. Guardamos los pronósticos.
  - Agregamos un dato y repetimos el paso anterior: estimamos los modelos para la muestra 2002:M2–2015:M3, pronosticamos 6 meses y guardamos los pronósticos.
  - Repetimos el paso anterior hasta la muestra 2002:M2–2019:M8, por lo que tenemos un conjunto de 55 pronósticos recursivos a un horizonte de 6 meses.
- ▶ Resultado: el modelo VAR(2) tiene un mejor desempeño predictivo que el modelo AR(2) para el caso de la inflación SAE bienes, pero no para la inflación SAE servicios. ¿Intuición?



# Aplicación: Pronósticos de la inflación (3/6)

Figure: Datos para el análisis



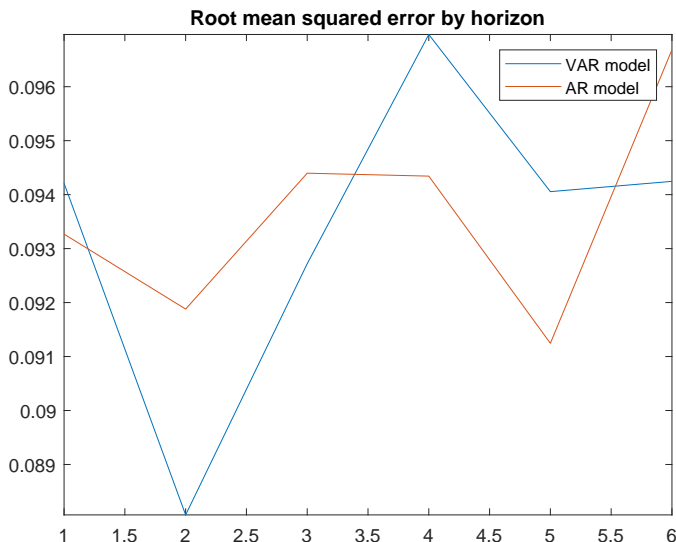
# Aplicación: Pronósticos de la inflación (4/6)

Figure: Pronósticos recursivos: inflación SAE



# Aplicación: Pronósticos de la inflación (5/6)

Figure: Raíz del error cuadrático medio por horizonte proy.: inflación SAE



# Aplicación: Pronósticos de la inflación (6/6)

Figure: RMSE: inflación SAE bienes

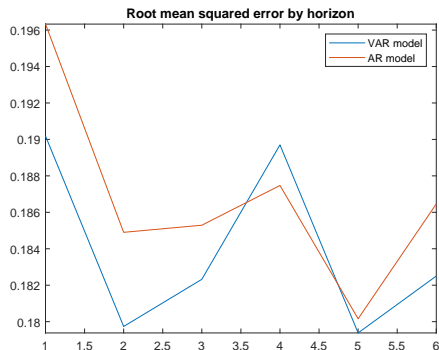


Figure: RMSE: inflación SAE servicios

